

ÎNVĂȚAREA AUTOMATĂ ACTIVĂ ȘI ÎNVĂȚAREA AUTOMATĂ PRIN TRANSFER APLICATE ÎN ANALIZA IMAGINILOR MEDICALE

Daniela Onița¹
Amalia Furdui²
Adriana Bîrluțiu³

ABSTRACT: În multe probleme de imagistică biomedicală, numai un expert poate analiza datele. Deși experții în domeniu sunt disponibili, munca lor este costisitoare și este de dorit să evităm să punem întrebări atunci când nu este neapărat nevoie. Sarcina noastră este să folosim cât mai eficient resursele existente pentru a facilita învățarea în cazul problemelor cu date de dimensiune redusă. Învățarea activă și învățarea prin transfer și-au demonstrat eficiența în a pregăti modele exacte, cu o cantitate semnificativ redusă de date în multe aplicații din viața reală. În această lucrare investigăm combinația dintre cele două tipuri de învățare pentru construirea unui algoritm eficient care să poată clasifica imaginile medicale.

Cuvinte cheie: Active Learning, Machine Learning, Transfer Learning

Introducere

Învățarea automată este o ramură a inteligenței artificiale care se ocupă cu proiectarea și dezvoltarea de algoritmi și metode care permit sistemelor informatice să învețe. Pe baza observațiilor și a experienței, sistemele informatice pot învăța să facă previziuni exacte și să ia decizii optime. Învățarea automată aplicată în medicină, și în special în analiza imaginilor medicale, este un subiect de cercetare foarte actual și cu rezultate promițătoare. Algoritmii de învățare automată, printr-un proces numit antrenare - adică învățare din exemple - sunt capabili să identifice, să clasifice și să eticheteze conținutul unei imagini. De exemplu, procesul de reconstrucție a imaginilor medicale care furnizează vederi bi și tri-dimensionale ale organelor interne ale pacienților folosește algoritmi de învățare automată pentru analiza și procesarea imaginilor. Acești algoritmi

¹ Universitatea 1 Decembrie 1918 Alba Iulia, Gabriel Bethlen Nr.5, 510009 Alba Iulia, danielaonita25@gmail.com

² Colegiul Economic Dionisie Pop Marțian, Specializarea Informatică-Economică, iulia_amalia@yahoo.com

³ Universitatea 1 Decembrie 1918 Alba Iulia, Gabriel Bethlen Nr.5, 510009 Alba Iulia, adriana.birlutiu@uab.ro

pot contribui astfel la întreg actul medical, începând cu diagnostic și până la tratament și intervenții.

Performanța algoritmilor de învățare automată folosiți în analiza imaginilor medicale depinde de datele de antrenare. Datele folosite pentru antrenare sunt însă limitate pentru că necesită etichetarea lor de către cadrele medicale. Cu cât există mai multe date care pot fi folosite pentru antrenarea algoritmilor, cu atât crește performanța și implicit calitatea imaginilor medicale. Învățarea automată prin transfer a apărut ca urmare a acestei nevoi de a include informații și date adiționale în procesul de învățare automată.

Învățarea automată prin transfer (Pan, Yang, 2010) s-a dezvoltat în cadrul învățării automate și a inteligenței artificiale ca o nouă paradigmă ce investighează modalitățile de a recunoaște și a aplica cunoștințe și abilități dobândite anterior pentru a rezolva sarcini noi dar similare cu cele anterior rezolvate. Ideea de bază din spatele algoritmilor de învățare automată prin transfer este că domeniile implicate conțin informații comune, dar ascunse care pot fi descoperite și exploatate folosind diferite tehnici și care reprezintă o punte de legătură pentru transferul cunoștințelor dobândite anterior. Învățarea automată prin transfer se inspiră din învățarea prin transfer din psihologie, mai precis din dependența învățării umane de experiența anterioară. Pe baza analogiei, se poate realiza transferul de la o problemă anterior rezolvată la o problemă țintă. Acest tip de învățare ridică următoarele întrebări: ce este analogia, cum sunt recunoscute analogiile, cum se transferă cunoștințele relevante? De exemplu, un sistem informatic conținând cunoștințe despre diagnosticarea defectelor din calculatoare poate învăța prin analogie diagnosticarea bolilor umane prin corelarea disfuncțiilor calculatorului cu simptomele pacienților, respectiv a unei metode de depanare cu tratamentul unei boli.

În ultimii ani algoritmii de învățare automată prin transfer au început să fie investigați pentru analiza imaginilor medicale pentru că s-a demonstrat prin studii științifice că aceștia duc la creșterea performanței actului medical (Heimann et al., 2014; van Opbroek et al., 2015; Zheng, 2015).

Descrierea problemei

Obiectivul lucrării este de a îmbunătăți tehnicile de învățare automată prin punerea împreună a două tehnici de învățare: învățarea activă și învățarea prin transfer. Primul pas este crearea unui model de clasificare pentru setul de date ales, folosind tehnici de învățare automată. Se dorește demonstrarea faptului că învățarea activă folosind una din strategiile de învățare se pretează mai bine în comparație cu alegerea aleatorie a punctelor

care urmează a fi adăugate setului de antrenare. Al doilea pas este combinarea învățării active și cea prin transfer pentru construirea unui algoritmul eficient care să poată clasifica imaginile medicale.

Criteriile de învățare activă pe care le propunem sunt similare cu cele introduse în (Birlutiu et al., 2013, Wang, 2016).

Învățarea activă, cunoscută și în literatura de specialitate ca *optimal experimental design*, este potrivită pentru situațiile în care etichetarea datelor este o activitate dificilă, consumatoare de timp și costisitoare. Ideea din spatele învățării active este ca prin selectarea optimă a datelor de antrenare, poate fi obținută o performanță mai bună față de selecția aleatoare a datelor ce vor fi folosite în antrenare. Scenariile în care învățarea activă poate fi aplicată fac parte din următoarele trei categorii: (i) generarea de date noi care urmează a fi etichetate; (ii) învățarea activă în fluxul de date, unde la fiecare moment se decide dacă să se solicite sau nu eticheta unei instanțe date; (iii) învățarea activă bazată pe selectarea punctului dintr-un set separat de date care conține și date neetichetate. În această lucrare considerăm al treilea scenariu pentru realizarea învățării active.

La nivelul acestei lucrări, pentru selectarea punctului care va fi adăugat la setul de antrenare, s-a folosit criteriul incertitudinii (Uncertainty Sampling Criterion). În cadrul acestei strategii se alege pentru etichetare acel punct pentru care previziunile modelului sunt cele mai nesigure. Incertitudinea din predicții poate fi măsurată, de exemplu, folosind entropia Shannon (Menendez, 2000).

Pentru un clasificator binar criteriul incertitudinii se reduce la selectarea punctelor ale căror probabilități de predicție sunt aproape de 0.5. Intuitiv, această strategie urmărește să determine cât mai rapid o performanță mare, deoarece acest criteriu al incertitudinii indică regiunile în care modelul este cel mai nesigur.

Învățarea de transfer (Pan, Yang, 2010) este o tehnică folosită pentru a transfera cunoștințele de la o sarcină de învățare sursă la o sarcină de învățare țintă. În contextul algoritmilor de învățare automată, învățarea de transfer poate fi implementată prin transferarea diferitelor elemente ale modelului învățat pe sarcina de învățare sursă către sarcina de învățare țintă. Învățarea prin transfer se utilizează atunci când datele de antrenare ale sarcinii țintă sunt de dimensiuni mai mici, similare, dar nu identice cu datele sarcinii sursă.

Evaluarea experimentală

Descrierea setului de date

Pentru clasificarea imaginilor s-a folosit setul Breast Cancer Histopathological Images Classification (BreakHis) (Spanhol et al., 2016). Acest set de date este format din imagini microscopice ale țesutului tumoral mamar, colectate de la 82 de pacienți. Imaginile utilizează diferiți factori de mărire (40X, 100X, 200X, 400X), așa cum este ilustrat în Fig. nr. 1.




Fig. nr. 1 – Diferite tipuri de tumori de sân observate în factori de mărire diferiți: (a) 40x, (b) 100x, (c) 200x, (d) 400x. Imaginile din partea stânga prezintă tumori benigne, iar cele din dreapta prezintă tumori maligne.

Imaginile sunt structurate după cum urmează:

Tabel nr. 1

Factor de mărire	Benign	Malign	Total
40X	640	1354	1994
100X	644	1437	2081
200X	623	1390	2013
400X	588	1095	1683

Fiecare imagine a fost convertită la scară gri și a fost redimensionată la 28x28, astfel o imagine este descrisă de un vector caracteristic 784-dimensional.

Imaginile au fost preprocesate folosind Principal Component Analysis (PCA). În prima fază, s-a efectuat centrarea datelor în jurul valorii zero: pentru fiecare porțiune a imaginii, valoarea medie a pixelilor a fost

calculată și scăzută din date. În a doua fază, dispersia datelor s-a adus în jurul valorii 1, în modul următor: i) s-a calculat matricea de covarianță a datelor și s-a realizat factorizarea SVD a matricei; ii) s-a realizat decorelarea datelor prin rotirea și reducerea dimensiunii; iii) datele decorelate au fost împărțite la valorile proprii.

Protocolul experimental

S-au comparat mai mulți algoritmi de învățare automată: Regresie logistică, Analiză discriminativă liniară, Arbori de decizie, Algoritmul Naive Bayes, Algoritmul Random Forest și Mașini cu suport vectorial (SVM).

Învățarea activă. S-a creat un model care a fost antrenat pe setul de date care cuprinde imaginile cu factor de mărire 40X, folosind algoritmul SVM. Setul de date a fost împărțit după cum urmează: 2% date de antrenament, 38% date neetichetate și 60% date pentru validare. Pentru compararea selecției punctelor în mod aleator și activ, aplicând criteriul incertitudinii s-a procedat după cum urmează.

- Un punct aleatoriu a fost selectat dintre datele neetichetate și a fost adăugat datelor de antrenament. După selectare, acest punct a fost șters din datele neetichetate. Pentru comparație, un punct a fost selectat în mod activ prin aplicarea criteriului incertitudinii. Pentru că avem un clasificator binar, a fost ales punctul unde probabilitățile de predicție (obținute pe date neetichetate cu modelul SVM) sunt mai apropiate de 0,5.

- După fiecare actualizare au fost făcute predicții pe setul de validare. S-a folosit acuratețea ca măsură a performanței.

Învățarea de transfer. Folosind același algoritm de învățare, SVM, s-a creat un model antrenat pe un set de date care cuprinde imaginile rămase în setul BreakHis (factorul de mărire 100X, 200X, 400X). Modelul a fost antrenat pe acest set mai mare, deoarece învățarea de transfer are sens atunci când datele modelului sursă sunt de dimensiuni mai mari decât ale modelului țintă. Acest model este utilizat în continuare pentru investigarea combinației dintre învățarea activă și învățarea transfer.

Învățarea activă + învățarea de transfer. Modelul creat pentru antrenarea setului de date 40X a fost de această dată antrenat folosind modelul pre-antrenat descris anterior. Restul procedurilor sunt identice cu cele de la selectarea punctelor în mod activ folosind criteriul incertitudinii.

Rezultate obținute

Rezultatele comparației algoritmilor de învățare sunt prezentate în Tabelul nr. 2. SVM funcționează cel mai bine, astfel se justifică folosirea lui în restul experimentelor.

Tabel nr. 2

Algoritm de învățare	Acuratețea (media \pm deviația standard)
SVM	0.66 \pm 0.0004
Regresie liniară	0.66 \pm 0.0004
Analiză discriminatorie liniară	0.57 \pm 0.002
Arbori de decizie	0.59 \pm 0.04
Naive Bayes	0.56 \pm 0.04
Random Forest	0.59 \pm 0.01

Figura 2, ilustrează comparația dintre acuratețea obținută prin selecția aleatoare și activă a datelor. Rezultatele obținute utilizând o selecție activă bazată pe criteriul incertitudinii sunt mai bune comparativ cu rezultatele obținute utilizând selecția aleatorie a datelor de antrenare.

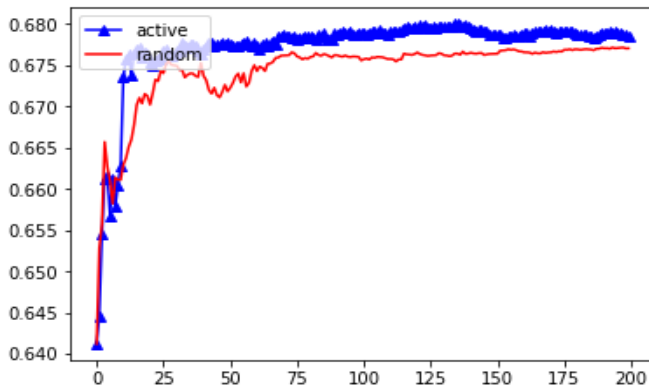


Fig. nr. 2. Comparație între selectarea aleatorie vs activă a datelor de antrenament.

Fig. nr. 3 prezintă comparația dintre acuratețea obținută folosind tehnici de învățare activă și acuratețea obținută prin combinarea învățării active cu învățarea de transfer. Combinația celor două tehnici de învățare are sens, acuratețea fiind vizibil îmbunătățită.

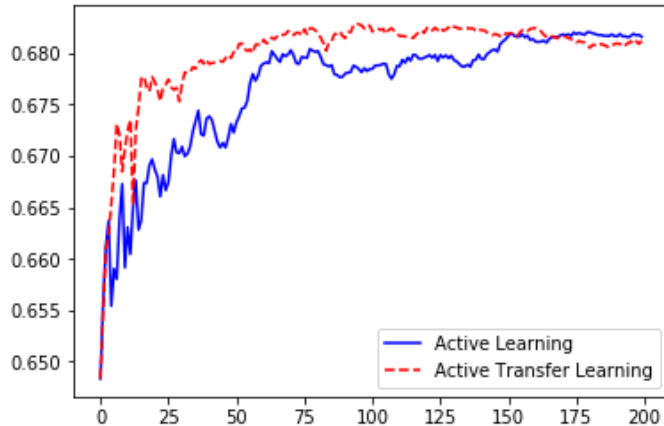


Fig. nr. 3. Active Learning vs Active Transfer Learning.

Concluzii

În această lucrare s-a demonstrat faptul că performanța algoritmilor de învățare automată pentru clasificarea imaginilor din domeniul biomedical poate fi crescută prin combinarea învățării active cu învățarea de transfer.

Există mai multe criterii de alegere a datelor de antrenare, iar cercetarea altor criterii este o primă direcție de dezvoltare. Deoarece este cunoscută performanța rețelelor neuronale convoluționale în probleme de imagistică medicală, o altă direcție de dezvoltare o reprezintă investigarea tehnicilor studiate în această lucrare folosind rețele neuronale convoluționale.

Bibliografie:

1. Birlutiu A., Groot P., Heskes T. (2013) Efficiently learning the preferences of people. *Machine Learning Journal*, 90 (1), pp.1-28, Springer, ISSN: 0885-6125.
2. Heimann T., Mountney P., John M., Ionasec R. (2014) Real-time ultrasound transducer localization in fluoroscopy images by transfer learning from synthetic training data. *Medical Image Analysis*. Vol 18, Issue 8, 1320-1328.
3. Menendez M.L. (2000) Shannon's entropy in exponential families: Statistical applications. *Applied Mathematics Letters*, Volume 13, Issue 1, January 2000, Pages 37-42.
4. van Opbroek A., Ikram M.A., Verno oij M.W., de Bruijne M. (2015) Transfer learning improves supervised image segmentation across imaging protocols. *IEEE Trans. Med. Imaging* 34(5): 1018-1030.

5. Pan S.J., Yang Q. (2010) A survey on transfer learning. IEEE Trans. Knowle. Data Eng. 2010;vol. 22, pp. 1345-1359.
6. Spanhol, F., Oliveira, L. S., Petitjean, C., Heutte, L. (2016) A Dataset for Breast Cancer Histopathological Image Classification, IEEE Transactions on Biomedical Engineering (TBME), 63(7):1455-1462.
7. Wang, X. (2016) Active Transfer Learning. PhD Thesis. BAE Systems.
8. Zheng Y. (2015) Cross-modality medical image detection and segmentation by transfer learning of shape priors. Proc. IEEE Intl Sym. Biomedical Imaging, 2015